

Sveučilište u Zagrebu  
Fakultet strojarstva i brodogradnje

# ZAVRŠNI RAD

Voditelj rada: Doc. dr. sc. Dragutin  
Lisjak

Hrvoje Herceg

Zagreb, 2011.

Sveučilište u Zagrebu  
Fakultet strojarstva i brodogradnje

# ZAVRŠNI RAD

Hrvoje Herceg

Zagreb, 2011.

## Sažetak

Ovaj završni rad daje uvid u primjenu "PROMETHEE" metodu višekriterijalnog odlučivanja . U radu je prikazano rješavanje problematike višekriterijalnih problema koji nastaju u slučajevima velikog broja kriterija koji su najčešće konfliktni. U tim se slučajevima primjenjuje neka od metoda višekriterijalnog odlučivanja, a u ovom radu prikazana je "PROMETHEE" metoda koja omogućuje odabir najbolje alternative, odnosno najboljeg kompromisnog rješenja. Za uspješno rješavanje višekriterijalnih problema, moraju biti poznate određene informacije kao što su preferencije (sklonosti) i prioriteti donosioca odluke. Na konkretnim primjerima, prikazan je rad sa "PROMETHEE" metodom koristeći softverski sustav "Decision Lab 2000".

Ključne riječi: višekriterijano odlučivanje , PROMETHEE, Decision Lab

---

## Izjava

Izjavljujem da sam rad izradio samostalno.

Želim zahvaliti svojem mentoru, doc. dr. sc. Dragutinu Lisjaku na pomoći i savjetima koji su mi pomogli da ovaj rad privedem kraju.

---

# Sadržaj

<b>Sadržaj</b>	<b>i</b>
<b>Popis slika</b>	<b>ii</b>
<b>Popis tablica</b>	<b>iv</b>
<b>Kazalo</b>	<b>v</b>
<b>1 Uvod</b>	<b>1</b>
<b>2 Višekriterijalno odlučivanje PROMETHEE metodom</b>	<b>2</b>
2.1 Višekriterijalno odlučivanje . . . . .	2
2.1.1 Metode "višeg ranga" (outranking methods) . . . . .	3
2.2 PROMETHEE metoda . . . . .	4
2.2.1 Modeliranje sklonosti (preference modelling) . . . . .	5
2.3 Geometrijska prezentacija rezultata (metoda GAIA) . . . . .	13
2.4 Opis aplikacije "Decision Lab" . . . . .	14
<b>3 Primjeri primjene PROMETHEE metode</b>	<b>16</b>
3.1 Odabir lokacije za izgradnju novog postrojenja . . . . .	16
3.2 Odabir automobila . . . . .	22
<b>4 Zaključak</b>	<b>28</b>
<b>Bibliografija</b>	<b>29</b>

## Popis slika

2.1	Graf funkcije općeg kriterija. . . . .	6
2.2	Graf funkcije običnog kriterija. . . . .	6
2.3	Graf funkcije kvazi kriterija. . . . .	7
2.4	Graf funkcije kriterija s linearnom preferencijom. . . . .	8
2.5	Graf funkcije kriterija sa razinama konstantne preferencije. . . . .	8
2.6	Graf funkcije kriterija s linearnom preferencijom i područjem indiferencije. . . . .	9
2.7	Graf funkcije Gaussovog kriterija. . . . .	9
2.8	Dijagram indeksa preferencije između $(n - 1)$ aktivnosti. . . . .	10
2.9	Izlazni $\Phi^+$ tok . . . . .	11
2.10	Ulazni $\Phi^-$ tok . . . . .	12
2.11	Glavni prozor Decision Lab-a . . . . .	14
2.12	PROMETHEE rangiranje, GAIA ravnina . . . . .	15
2.13	Podesive težine kriterija $w$ . . . . .	15
3.1	Glavni prozor, unos podataka . . . . .	18
3.2	Izlazni, ulazni i čisti tok . . . . .	18
3.3	Intervali stabilnosti . . . . .	19
3.4	Težina kriterija . . . . .	19
3.5	Aktivna usporedba lokacija . . . . .	20
3.6	PROMETHEE II potpuno rangiranje . . . . .	20
3.7	PROMETHEE I parcijalno rangiranje . . . . .	21
3.8	GAIA ravnina . . . . .	21
3.9	Najprodavanije marke automobila 2010. godine u Hrvatskoj . . . . .	23
3.10	Najprodavaniji modeli automobila 2010. godine u Hrvatskoj . . . . .	24
3.11	Unos podataka . . . . .	24
3.12	PROMETHEE II potpuno rangiranje . . . . .	25
3.13	PROMETHEE I parcijalno rangiranje . . . . .	25
3.14	Intervali stabilnosti . . . . .	25
3.15	GAIA ravnina . . . . .	26
3.16	Težina kriterija . . . . .	27

3.17 Izlazni, ulazni i čisti tok . . . . .	27
--	----

---

## Popis tablica

3.1	Šest odlučujućih kriterija za usporedbu lokacija . . . . .	17
3.2	Težina kriterija . . . . .	17
3.3	Kriteriji za usporedbu automobila . . . . .	22
3.4	Težina kriterija . . . . .	23



---

## Kazalo

- $A$  konačni skup aktivnosti
- $f_i$  kriterij
- $a, b$  alternative
- $P(d), H(d)$  funkcija preferencije
- $d$  razlika vrijednosti dviju aktivnosti
- $q$  indiferencija
- $p$  preferencija
- $w$  težina kriterija
- $\Pi$  višekriterijalni indeks preferencije
- $\Phi^+$  izlazni tok
- $\Phi^-$  ulazni tok
- $\Phi$  čisti tok

## Uvod

Za temu završnog rada odabran je opis "PROMETHEE" metode, njezina primjena u višekriterijanom odlučivanju uz pomoć aplikacije "Decision Lab". Pojava višekriterijalnih problema prilikom kojih je donosioc odluke primoran birati između nekoliko konfliktnih rješenja postaje sve češća u poslovnom svijetu, stoga poznavanje metoda za rješavanje višekriterijalnih problema postaje od iznimne važnosti. "PROMETHEE" metoda, uz dovoljan broj informacija i pravilno definirane preferencije donosioca odluke, postaje iznimno efikasan alat za rješavanja višekriterijalnih problema, te se uz pomoć aplikacije "Decision Lab" primjena i analiza rezultata "PROMETHEE" metode odvija preciznije i detaljnije.

U prvom poglavlju opisana je problematika višekriterijalnog odlučivanja, opis same "PROMETHEE" metode, te aplikacije Decision Lab koja se koristi za rješavanje višekriterijalnih problema. U drugom je poglavlju na dva primjera prikazano rješavanje problema višekriterijalnog odlučivanja "PROMETHEE" metodom korištenjem "Decision Lab" aplikacije.

# Višekriterijalno odlučivanje PROMETHEE metodom

## 2.1 Višekriterijalno odlučivanje

Na višim razinama odlučivanja proces donošenja odluka, po svojim karakteristikama, pripada višekriterijalnom odlučivanju koje se koristi u situacijama kada postoji veći broj, najčešće konfliktnih kriterija [1].

Karakteristike višekriterijalnog odlučivanja:

- veći broj kriterija
- konflikti između kriterija
- neusporedive jedinice mjere
- rješenje ovakve vrste problema je projektiranje najbolje akcije (alternative) ili izbor najbolje iz prethodno definiranog skupa akcija

Za rješavanje konkretnih problema višekriterijalnog odlučivanja razrađene su u osnovi tri vrste metoda:

- metode agregiranja koje koriste funkcije korisnosti (utility functions)
- razne interaktivne metode (metode "cjenkanja")
- metode "višeg ranga" (outranking methods)

### 2.1.1 Metode "višeg ranga" (outranking methods)

U praksi je zapaženo da metode "višeg ranga" izbijaju u prvi plan, kako zbog svoje prilagodljivost stvarnim problemima (koji su u načelu slabo strukturirani), tako i zbog činjenice da su, u usporedbi sa sličnim metodama razumljivije donositelju odluka.

Svaka metoda "višeg ranga" uključuje dvije faze:

- sastavljanje relacije "višeg ranga",
- korištenje ove relacije kao pomoć donositelju odluke.

Navedene se faze mogu tretirati na različite načine, tako da su predložene različite metode, ovisno o vrsti problema i konkretnih situacija. Ako donositelj odluke želi rangirati skup alternativa, sustava, čvorova, projekata itd. od najboljeg do najlošijeg, tada se govori o problemu rangiranja. Ako donositelj odluke mora izabrati najbolju akciju, sustav itd., govorimo o problemu izbora. Kako kod većine višekriterijalnih problema, općenito, nema najboljeg rješenja, odluka se svodi na određivanje skupa dobrih alternativa, sustava, čvorova, projekata itd.

Neke metode "višeg ranga":

- ELECTRE
- PROMETHEE
- AHP

## 2.2 PROMETHEE metoda

Metodu je razvio Jean-Pierre Brans i predstavio po prvi put 1982. godine na konferenciji koju je organizirao R. Nadeau i M. Landry na Université Laval, Québec, Canada (L'Ingénierie de la Décision. Elaboration d'instruments d'Aide à la Décision). Iste godine metoda se počela primjenjivati na probleme vezane za zdravstvo, a kasnijim razvojem PROMETHEE metoda dobiva svoju primjenu u različitim područjima kao što su bankarstvo, kemijska industrija, medicina, turizam, itd. PROMETHEE metoda svoj uspjeh i popularnost može zahvaliti prvenstveno svojim matematičkim svojstvima i lakoći primjene.

Metoda PROMETHEE (**P**reference **R**anking **O**rganization **METH**od for **E**nrichment **E**valuations) spada u grupu metoda za višekriterijski izbor u skupu alternativa opisanih s više atributa koji se koriste kao kriteriji. Razvijeno je šest PROMETHEE metoda od kojih su u ovom završnom radu opisane prve dvije: PROMETHEE I (parcijalno rangiranje) i PROMETHEE II (potpuno rangiranje) [1].

Promotrimo višekriterijski problem:

$$Max(f(a), \dots, f_k(a))|_{a \in A} \quad (2.1)$$

gdje je  $A$  konačni skup aktivnosti, a  $f_i, i = 1, \dots, k$  su kriteriji koristi koje treba maksimizirati ili zadovoljiti po principu "veće je bolje" (ovo je pretpostavka koja omogućuje jednostavniju prezentaciju metode – u slučaju kada su neki od kriterija kriteriji troškova oni se mogu transformirati u kriterije koristi, ili se postupak prilagodi i tim kriterijima).

Primjenu PROMETHEE metode karakteriziraju dva koraka:

- konstrukcija relacije preferencije za svaki kriterij  $f_i$  u skupu alternativa  $A$  (modeliranje sklonosti),
- korištenje te relacije da bi se odgovorilo na problem 2.1

U prvom koraku, formira se složena relacija preferencije (da bi se naglasila činjenica da se ta relacija temelji na uvažavanju više kriterija, ta relacija se u originalu naziva outranking relation) zasnovana na poopćenju pojma kriterija. Definira se indeks preferencija i dobiva se složena relacija preferencije koja se prikazuje pomoću grafa preferencije. Suština ovog koraka je ta da donositelj odluke mora izraziti svoje preferencije između dvije alternative (akcije, aktivnosti), po svakom od kriterija, na temelju razlike kriterijalnih

vrijednosti alternativa koje uspoređuje. Na taj način konstruirana relacija preferencije upotrebljava se tako da se za svaku alternativu izračunaju ulazni i izlazni tok u grafu. Na temelju tih tokova donositelj odluke može u skup alternativa uvesti parcijalni uređaj (PROMETHEE I) ili potpuni uređaj (PROMETHEE II) [2].

### 2.2.1 Modeliranje sklonosti (preference modelling)

Neka je  $f$  realna funkcija kojom se izražava jedan od atributa koji se upotrebljava kao kriterij za uspoređivanje alternativa:

$$f : A \rightarrow \mathbb{R} \quad (2.2)$$

pretpostavimo da se radi o kriteriju koristi, tj. da se po tom kriteriju alternative uspoređuju poštujući princip "veće je bolje".

Za svaku alternativu  $a \in A$ ,  $f(a)$  je pripadna kriterijalna vrijednost po kriteriju  $f$ . Kada se uspoređuju dvije alternative  $a, b \in A$ , rezultat te usporedbe izražava se u obliku preferencije.

Funkcijom preferencije  $P$

$$P : A \times A \rightarrow [0, 1] \quad (2.3)$$


izražava se intenzitet preferencije alternative  $a$  u odnosu na alternativu  $b$  sa slijedećom interpretacijom:

- $P(a, b) = 0$  znači indiferenciju između  $a$  i  $b$ , tj. nema preferencije  $a$  nad  $b$ ,
- $P(a, b) \approx 0$  znači slabu preferenciju  $a$  nad  $b$ ,
- $P(a, b) \approx 1$  znači jaku preferenciju  $a$  nad  $b$ ,
- $P(a, b) = 1$  znači strogu preferenciju  $a$  nad  $b$ .

Funkcija preferencije koja se pridružuje pojedinom kriteriju je funkcija razlike kriterijalnih vrijednosti alternativa, pa se može pisati:

$$P(a, b) = P(f(a) - f(b)) = P(d) \quad (2.4)$$

$P(d)$  je neopadajuća funkcija koja poprima vrijednost nula za negativne vrijednosti razlike  $d = f(a) - f(b)$ . Graf funkcije općeg kriterija s navedenim svojstvima prikazan je na slici 2.1.




Slika 2.1: Graf funkcije općeg kriterija.

Postoji šest tipova funkcija tzv. općih kriterija koji se najčešće koriste u praktičnim primjenama i dovoljni su za rješavanje većine praktičnih problema, a kod kojih nosioc odluke određuje najviše dva parametra [2]:

1) Običan kriterij

$$H(d) = \begin{cases} 0, & d = 0 \\ 1, & d \neq 0 \end{cases} \quad (2.5)$$

U ovom slučaju postoji indiferencija između alternativa a i b ako i samo ako je  $f(a) = f(b)$ ; čim se te vrijednosti razlikuju, donositelj odluke ima strogu preferenciju za aktivnost koja ima veću vrijednost. Funkcija H prikazana je grafom na 2.2. U ovom slučaju nije potrebno definirati nikakve parametre.




Slika 2.2: Graf funkcije običnog kriterija.

## 2) Kvazi kriterij

$$H(d) = \begin{cases} 0, & -q \leq d \leq q \\ 1, & |d| > q \end{cases} \quad (2.6)$$

Kao što se može vidjeti na slici 2.3, dvije aktivnosti su za donositelja odluke indiferentne, sve dok razlika između njihovih vrijednosti  $d$  ne prekorači prag indiferencije  $q$ , a kada ga prekorači, radi se o strogoj preferenciji.



Slika 2.3: Graf funkcije kvazi kriterija.

## 3) Kriterij s linearnom preferencijom


$$H(d) = \begin{cases} \frac{d}{p}, & -p \leq d \leq p \\ 1, & |d| > p \end{cases} \quad (2.7)$$

Sve dok je  $d$  manji od  $p$ , preferencija donositelja odluke linearno raste s  $d$ , a kad  $d$  postane veći od  $p$ , nastaje situacija stroge preferencije. Donositelj odluke mora odrediti vrijednost praga preferencije  $p$ , a to je najmanja vrijednost  $d$  koja uzima u obzir postojanje stroge preferencije jedne od odgovarajućih aktivnosti. Graf na slici 2.4 prikazuje funkciju trećeg tipa.

## 4) Kriterij s razinama konstantne preferencije


$$H(d) = \begin{cases} 0, & |d| \leq q \\ \frac{1}{2}, & q < d \leq p \\ 1, & p < |d| \end{cases} \quad (2.8)$$





Slika 2.4: Graf funkcije kriterija s linearnom preferencijom.

U ovom slučaju prag indiferencije  $q$  i prag preferencije  $p$  su istovremeno definirani. Oni u praksi ne moraju biti jednaki. Ako  $d$  leži između  $q$  i  $p$ , imamo slučaj slabije preferencije. Funkcija je predstavljena grafom na slici 2.5.




Slika 2.5: Graf funkcije kriterija sa razinama konstantne preferencije.

##### 5) Kriterij s linearnom preferencijom i područjem indiferencije

$$H(d) = \begin{cases} 0, & |d| \leq q \\ \frac{|d| - q}{p - q}, & q < |d| \leq p \\ 1, & p < |d| \end{cases} \quad (2.9)$$

U ovom slučaju donositelj odluke smatra da njegova preferencija raste linearno u području između dva praga  $q$  i  $p$ , i to od indiferentnosti do stroge preferencije.

Dakle treba definirati 2 parametra. Funkcija je prikazana grafom na slici 2.6.




Slika 2.6: Graf funkcije kriterija s linearnom preferencijom i područjem indiferencije.

6) Gaussov kriterij

$$H(d) = 1 - e^{\frac{-d^2}{2\sigma^2}} \quad (2.10)$$

Funkcija je prikazana grafom na slici 2.7. Budući da nema prekida interesantna je zbog osigurane stabilnosti rezultata. Potrebno je jedino odrediti parametar normalne distribucije  $\sigma$ , koji se također određuje na temelju ekonomskih argumenata.



Slika 2.7: Graf funkcije Gaussovog kriterija.

Višekriterijalni index preferencije


Pretpostavimo da je donositelj odluke odredio funkciju preferencije  $P_i$  i težinu  $w_i$  za svaki kriterij  $f_i (i = 1, \dots, k)$  problema 2.1. Težina  $w_i$  je mjera relativne važnosti kriterija  $f_i$ . Ako svi kriteriji imaju istu važnost za donositelja odluke, sve težine su jednake. Višekriterijalni indeks preferencije

$$\Pi(a, b) = \frac{\sum_{i=1}^k w_i P_i(a, b)}{\sum_{i=1}^k w_i} \quad (2.11)$$

$\Pi(a, b)$  predstavlja intenzitet, odnosno jakost preferencije donositelja odluke za aktivnost  $a$  nad aktivnošću  $b$ , kad istovremeno uspoređujemo sve kriterije. Varira između vrijednosti 0 i 1.

- $\Pi(a, b) \approx 0$  - označava slabu preferenciju  $a$  nad  $b$  za sve kriterije,
- $\Pi(a, b) \approx 1$  - označava jaku preferenciju  $a$  nad  $b$  za sve kriterije.

Između dva čvora (dvije aktivnosti)  $a$  i  $b$  postoje dva luka koji imaju vrijednosti  $\Pi(a, b)$  i  $\Pi(b, a)$ . Ovaj odnos prikazan je slikom 2.8.




Slika 2.8: Dijagram indeksa preferencije između  $(n - 1)$  aktivnosti.

#### Izlazni i ulazni tok

Svaka alternativa  $a$  usmjerena je prema  $(n - 1)$  alternativa u  $A$ . Definirajmo sada izlazni i ulazni tok:

- a) izlazni tok je zbroj vrijednosti izlaznih lukova

$$\Phi^+(a) = \frac{1}{n-1} \sum_{x \in A} \Pi(a, x) \quad (2.12)$$

Slika 2.9: Izlazni  $\Phi^+$  tok


- b) ulazni tok je zbroj vrijednosti ulaznih lukova:

$$\Phi^-(a) = \frac{1}{n-1} \sum_{x \in A} \Pi(x, a) \quad (2.13)$$

Izlazni tok  $\Phi^+(a)$  pokazuje dominaciju alternative  $a$  nad drugim alternativama, te što je  $\Phi^+$  veći to je alternativa bolja. Ulazni tok  $\Phi^-(a)$  pokazuje dominaciju drugih alternativa nad alternativom  $a$ , te što je  $\Phi^-$  manji to je alternativa bolja.

#### PROMETHEE I (parcijalno rangiranje)

Na temelju ulaznog i izlaznog toka može se izvršiti parcijalni poredak PROMETHEE I. Naime, što je viši izlazeći tok i što je niži ulazeći, to je bolja aktivnost. Dakle, što je veći  $\Phi^+(a)$ , to aktivnost  $a$  više dominira nad ostalim aktivnostima u  $A$ . S druge strane, što je  $\Phi^-(a)$  manji, to manje ostale aktivnosti dominiraju nad aktivnošću  $a$ . PROMETHEE I daje donosiocu odluke puno veći opseg informacija od PROMETHEE II metode, ali u nekim slučajevima događa se da pri izračunu tokova dolazi do njihove nedosljednosti i PROMETHEE I uzima alternative kao neusporedive i u takvom slučaju prebacuje odgovornost na samog donosioca odluke.

Slika 2.10: Ulazni  $\Phi^-$  tok

## PROMETHEE II (potpuno rangiranje)

Ako donositelj odluke želi potpuni poredak (bez neusporedivosti), promatra se čisti tok:

$$\Phi(a) = \Phi^+(a) - \Phi^-(a) \quad (2.14)$$

U ovom potpunom poretku PROMETHEE II sve aktivnosti u  $A$  su potpuno rangirane, ali ovaj odnos je također siromašniji u informacijama i manje je realan, jer dolazi do balansiranja efekata između izlazećih i ulazećih tokova.

## 2.3 Geometrijska prezentacija rezultata (metoda GAIA)

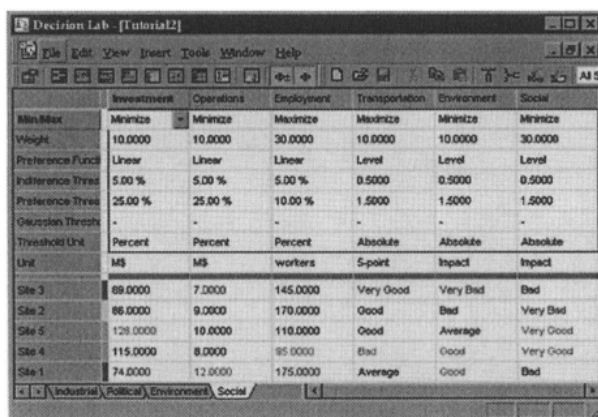
Pri korištenju metode PROMETHEE za rješavanje problema višekriterijalnog odlučivanja, dva temeljna rezultata su: PROMETHEE I (parcijalno rangiranje alternativa koje daje veliki opseg informacija međutim ostavlja neke alternative međusobno neusporedivima) i PROMETHEE II (potpuno rangiranje svih alternativa). Međutim, imajući u vidu postojanje alternativa koje se međusobno ne mogu usporediti (tj. od kojih ne možemo strogo odabrati "bolju" i "lošiju"), kao i mogućnost da pri potpunom rangiranju alternativa u PROMETHEE II, razlike ukupnog toka među nekim alternativama budu vrlo male (što uvjetuje izvjesnu nepouzdanost potpunog rangiranja, npr. uz malu izmjenu težina kriterija poredak bi se promijenio), javlja se potreba za dodatnom geometrijskom informacijom o "ponašanju" alternativa prema pojedinim kriterijima. Ovakva informacija omogućava donosiocu odluke potpuniji uvid u odnos alternativa prema kriterijima, olakšava predviđanja "što ako" situacija i omogućava razumljivu i efektanu prezentaciju rezultata dobivenih korištenjem metode PROMETHEE.

Metoda GAIA (Geometrical Analysis for Interactive Aid) daje geometrijsku prezentaciju rezultata PROMETHEE metode. Ideja na kojoj se zasniva metoda je svođenje višedimenzionalnog problema na dvodimenzionalni kako bi se omogućila ravninska prezentacija. Naime, po svojoj prirodi, dimenzija višekriterijalne analize određena je brojem kriterija (svaki kriterij određuje jedan vektor u takvom prostoru) i jasno je da, ako se želi "razumnu" geometrijsku prezentaciju, problem treba svesti u okvire dvodimenzionalnog svijeta (eventualna trodimenzionalna prezentacija bila bi znatno nepreglednija.) Pri ovom smanjivanju dimenzije nužan je izvjestan gubitak informacija o samom problemu, ali osim pri izuzetno nepovoljnoj strukturi problema, geometrijska prezentacija daje dovoljno visok postotak informacija za sagledavanje problema. Moguće je također povezati metodu GAIA s metodom PROMETHEE II potpunim rangiranjem. PROMETHEE II zahtijeva da se svakom kriteriju pridruži određeni težina  $w_i$  i gradi kompletni poredak u skupu A. Težine kriterija se također mogu prikazati u GAIA ravnini pomoću tzv. "osi odluke" koja je usmjerena u smjeru najbolje rangiranih alternativa. Na taj je način moguće interaktivnim mijenjanjem težina promatrati posljedice na rangiranje dobiveno s PROMETHEE II. Korištenjem softverskog paketa GAIA mo-

guće je dobiti numeričke rezultate i grafove koji pomažu donosiocu odluke da realnije sagleda problem i dobije potpuniji uvid u odnose među kriterijima i alternativama. [7]

## 2.4 Opis aplikacije "Decision Lab"

Decision Lab je softver koji se koristi za implementaciju PROMETHEE metode, razvijen od strane kanadske tvrtke Visual Decision. Decision Lab je windows aplikacija koja koristi tipično spreadsheet sučelje (proračunsku tablicu) za upravljanje i obradu podataka višekriterijalnih problema. Svi podaci se odnose na PROMETHEE metodu mogu se lako definirati i unesti od strane korisnika. Osim toga, Decision Lab omogućuje korisniku korištenje dodatnih aplikacija kao što su definiranje kvalitativnih kriterija, obrada vrijednosti koje nedostaju u višekriterijskoj tablici ili definiciju postotka granica u preferencijskim funkcijama, sve u svrhu olakšanja analize višekriterijalnog problema. Svi proračuni unutar Decision Lab-a se odvijaju u realnom vremenu i bilo kakva preinaka podataka je odmah vidljiva u izlaznom prozorčiću aplikacije [2],[15].

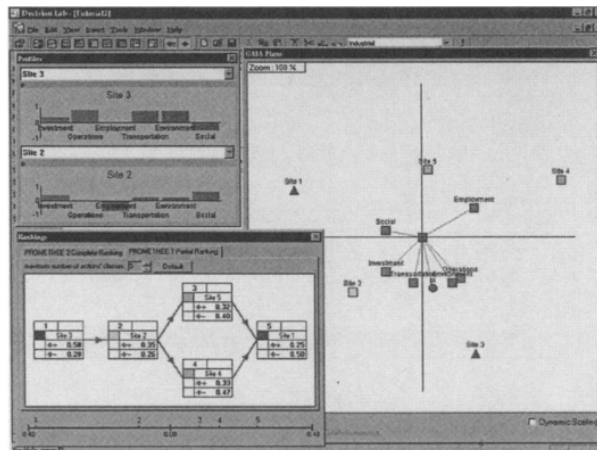


The screenshot shows the 'Decision Lab - [Tutorial2]' window. It features a menu bar (File, Edit, View, Insert, Tools, Window, Help) and a toolbar. The main area is a spreadsheet with columns for 'Investment', 'Operations', 'Employment', 'Transportation', 'Environment', and 'Social'. The rows include criteria definitions (Min/Max, Weight, Preference Function, Indifference Threshold, Preference Threshold, Outranking Threshold, Threshold Unit) and data for five sites (Site 1 to Site 5). The bottom status bar shows the active tab is 'Social'.

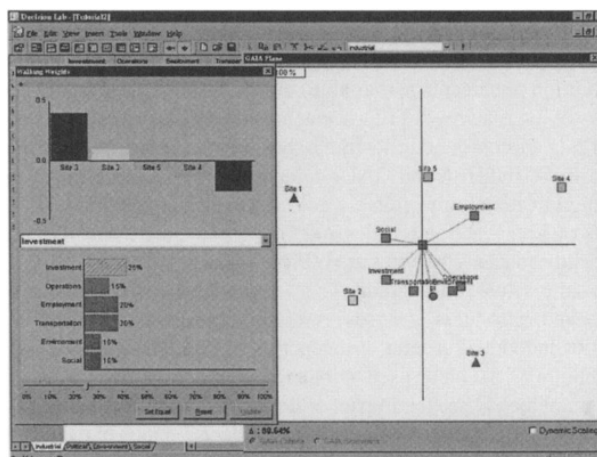
	Investment	Operations	Employment	Transportation	Environment	Social
Min/Max	Minimize	Minimize	Maximize	Maximize	Minimize	Minimize
Weight	10.0000	10.0000	30.0000	10.0000	10.0000	30.0000
Preference Funct	Linear	Linear	Linear	Level	Level	Level
Indifference Thres	5.00 %	5.00 %	5.00 %	0.5000	0.5000	0.5000
Preference Thres	25.00 %	25.00 %	10.00 %	1.5000	1.5000	1.5000
Outranking Thresh	-	-	-	-	-	-
Threshold Unit	Percent	Percent	Percent	Absolute	Absolute	Absolute
Unit	M\$	M\$	workers	S-point	Impact	Impact
Site 5	89.0000	7.5000	145.0000	Very Good	Very Bad	Bad
Site 2	86.0000	9.0000	170.0000	Good	Bad	Very Bad
Site 5	128.0000	10.0000	110.0000	Good	Average	Very Good
Site 4	115.0000	8.0000	95.0000	Bad	Good	Very Good
Site 1	74.0000	12.0000	175.0000	Average	Good	Bad

Slika 2.11: Glavni prozor Decision Lab-a

## 2.4. Opis aplikacije "Decision Lab"



Slika 2.12: PROMETHEE rangiranje, GAIA ravnina



Slika 2.13: Podesive težine kriterija  $w$



## Primjeri primjene PROMETHEE metode

### 3.1 Odabir lokacije za izgradnju novog postrojenja

Kao i za većinu problema odlučivanja, odabir lokacije uključuje izbor između nekoliko mogućih alternativa, dok je više kriterija u igri. Prilikom izrade ovoga primjera uzeti su isključivo proizvoljni podaci [15]. Uzeto je pet potencijalnih lokacija (npr. Kanada, Brazil, Njemačka, Kina, Australija), te su proizvoljno uzeti osnovni kriteriji po kojima će se uspoređivati lokacije, odnosno alternative :

- a) Različiti troškovi (npr. troškovi ulaganja, operativni troškovi i trošak radne snage)
- b) Važnost razvijene lokalne transportne mreže
- c) Utjecaj na društvo i okoliš

U većini slučajeva ni jedna opcija ne zadovoljava sve kriterije u isto vrijeme i zato je važno odabrati najbolje kompromisno rješenje. Prilikom izbora lokacije moraju se uzeti u obzir kriteriji različitih sudionika koji su uključeni u ovaj projekt odabira i izgradnje novog postrojenja (bilo direktno ili indirektno) :

- a) Investitor (tvrtka koja gradi postrojenje)
- b) Vlada (zemlje iz koje je tvrtka i zemlje u kojoj će se postrojenje graditi)
- c) Društvene i ekološke udruge (sindikati, vlasnici zemlje gdje će se graditi postrojenje)

### 3.1. Odabir lokacije za izgradnju novog postrojenja

Kriterij	Jedinica/Skala
Troškovi ulaganja	Milijuni američkih dolara
Operativni troškovi	Milijuni američkih dolara
Nova radna mjesta	Broj radnika
Razvijenost prometne mreže	Opisna skala(od vrlo slaba do vrlo dobra)
Utjecaj na okoliš	Opisna skala(od vrlo nizak do vrlo visok)
Utjecaj na društvo	Opisna skala(od vrlo nizak do vrlo visok)

Tablica 3.1: Šest odlučujućih kriterija za usporedbu lokacija

Kriterij	Težina kriterija
Troškovi ulaganja	25
Operativni troškovi	15
Nova radna mjesta	20
Razvijenost prometne mreže	20
Utjecaj na okoliš	10
Utjecaj na društvo	10

Tablica 3.2: Težina kriterija

Pretpostavljeno je da su se svi sudionici odluke usuglasili oko šest odlučujućih kriterija za usporedbu potencijalnih lokacija, tablica 3.1


Također je veoma važno da donositelj odluke izrazi svoje preferencije po svakom od kriterija u tablici. Na taj način konstruirana relacija preferencije upotrebljava se tako da se za svaku lokaciju izračunaju ulazni i izlazni tok. Na temelju tih tokova donositelj odluke može uvesti parcijalni uređaj (PROMETHEE I) ili potpuni uređaj (PROMETHEE II). Ne moraju svi kriteriji biti jednaki već neki mogu imati veću težinu  $w$  u odnosu na druge. Težina kriterija je pozitivna vrijednost i nezavisna je u odnosu na jedinice/skale kojima smo izražavali kriterije. Znači, što je veća težina kriterija to je taj kriterij važniji, tablica 3.2

Nakon što su uzeti u obzir svi podatci za svaki pojedini kriterij postavlja se pitanje minimiziranja nekih kriterija (troškovi ulaganja, operativni troškovi, zapošljavanje, utjecaj na okoliš, utjecaj na društvo), te maksimiziranja drugih (razvijenost prometne mreže) u svrhu dobivanja što pogodnijih podataka za donositelja odluke. Posljednji parametar koji je potrebno odabrati jest tip preferencijska funkcija za svaki kriterij. U ovom slučaju za prva 3 kriterija (troškovi ulaganja, operativni troškovi, zapošljavanje)

### 3.1. Odabir lokacije za izgradnju novog postrojenja

primjenjen je linearni kriterij s područjem indiferencije, te su proizvoljno odabrane granice preferencije i indiferencije (P i Q), a za ostala 3 kriterija (utjecaj na okoliš, utjecaj na društvo, razvijenost prometne mreže) primjenjen je kriterij s razinama preferencije i također proizvoljno odabrane granice preferencije i indiferencije (P i Q).

Nakon što su određeni kriterije po kojima će se uspoređivati lokacije i zadanei preferencije donositelja odluke, podaci se unose u Decision Lab proračunsku tablicu tako da se kriteriji upisuju u stupce, a lokacije koje će se uspoređivati u redove, te se postupno unose svi ostali podaci.



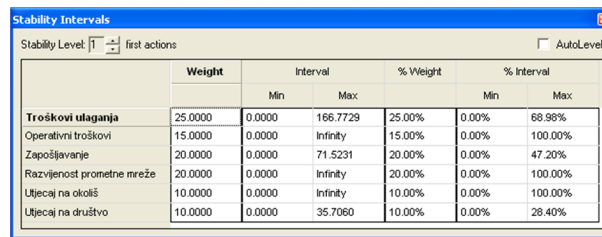
Slika 3.1: Glavni prozor, unos podataka

Preference Flows			
	$\Phi^+$	$\Phi^-$	$\Phi$
Kan.	0.2525	0.4969	-0.2444
Bra.	0.3469	0.2592	0.0876
Nje.	0.5764	0.1995	0.3768
Kin.	0.3307	0.4691	-0.1384
Aus.	0.3219	0.4036	-0.0817

Slika 3.2: Izlazni, ulazni i čisti tok


Za svaki kriterij Decision Lab izračunava njegov interval stabilnosti koji pokazuje u kojim se granicama težina pojedinog kriterija može mijenjati a da se ne promijene rezultati PROMETHEE II rangiranja uz uvjet da se ostale težine kriterija ne mijenjaju, slika 3.3

### 3.1. Odabir lokacije za izgradnju novog postrojenja



	Weight	Interval		% Weight	% Interval	
		Min	Max		Min	Max
<b>Troškovi ulaganja</b>	25.0000	0.0000	166.7729	25.00%	0.00%	68.98%
Operativni troškovi	15.0000	0.0000	Infinity	15.00%	0.00%	100.00%
Zapošljavanje	20.0000	0.0000	71.5231	20.00%	0.00%	47.20%
Razvijenost prometne mreže	20.0000	0.0000	Infinity	20.00%	0.00%	100.00%
Utjecaj na okoliš	10.0000	0.0000	Infinity	10.00%	0.00%	100.00%
Utjecaj na društvo	10.0000	0.0000	35.7060	10.00%	0.00%	28.40%

Slika 3.3: Intervali stabilnosti




Slika 3.4: Težina kriterija

Lokacije su poredane od najbolje prema najgoroj, te kao dodatna informacija prikazana je međusobna numerička udaljenost između lokacija, slika 3.6


Lokacije su rangirane isključivo prema snažno uspostavljenim preferencijama i kao posljedica toga se neke lokacije ne mogu direktno uspoređivati (Kina i Australija), slika 3.7

GAIA (Graphical Analysis for Interactive Aid) ravnina je grafički dodatak PROMETHEE rangiranju, a njezinim proučavanjem se može dobiti obilje korisnih podataka kao što su slabe i jake značajke svake lokacije, a smjer “osi odluke” pokazuje nam idealno rješenje, odnosno idealnu lokaciju, slika 3.8

### 3.1. Odabir lokacije za izgradnju novog postrojenja

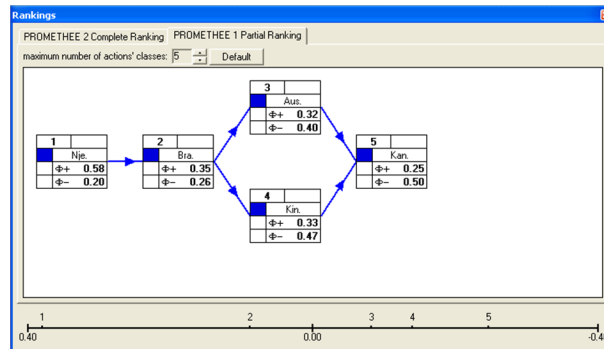


Slika 3.5: Aktivna usporedba lokacija

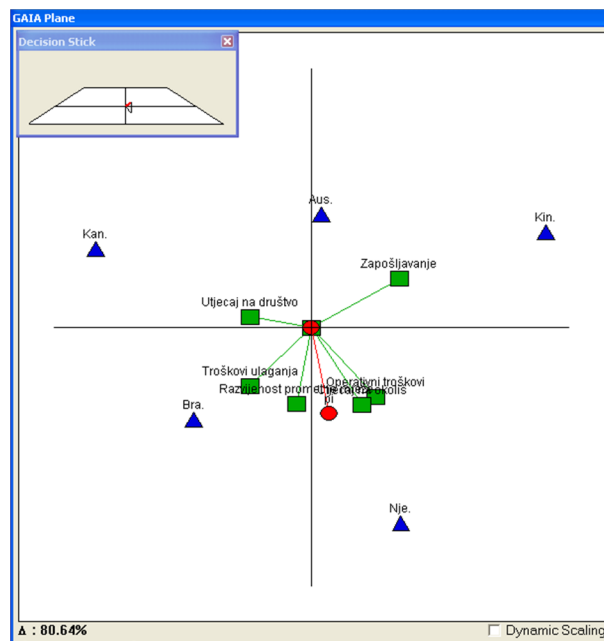


Slika 3.6: PROMETHEE II potpuno rangiranje

### 3.1. Odabir lokacije za izgradnju novog postrojenja



Slika 3.7: PROMETHEE I parcijalno rangiranje



Slika 3.8: GAIA ravnina

## 3.2 Odabir automobila

Kako bi se došlo do što preciznijih podataka stupljeno je u kontakt s tvrtkom Promocija plus koja se bavi istraživanjem tržišta, te je ustanovljeno da je u 2010. godini deset najprodavanijih marki automobila : Opel, Volkswagen, Renault, Chevrolet, Peugeot, Hyundai, Škoda, Ford, Citroen i Kia, slika (3.9). Tijekom rujna i listopada 2010., na uzorku većem od 600 ispitanika, vodeći hrvatski web oglasnik za vozila, 4Kotača, proveo je istraživanje o navikama pri kupnji automobila [13]. U istraživanju su većinom sudjelovali muškarci, odnosno njih čak 84 posto. Kad je riječ o dobi, 39 posto ispitanika ima između 26 i 35 godina, a onih starijih od 46 godina je 20 posto. Najviše ispitanika (29 posto) za automobil je spremno odvojiti između 10.000 i 15.000 eura. Kada je u pitanju klasa automobila, najviše bi ispitanika (36 posto) kupilo kompaktni automobil kao što su Volkswagen Golf i Opel Astra, slika (3.10). Nakon pregledanih rezultata istraživanja odlučili smo se za odabir između pet alternativa, odnosno automobila koji su zadnjih godina u vrhu prodaje u Republici Hrvatskoj [14]:

- Volkswagen Golf
- Opel Astra
- Ford Focus
- Škoda Octavia
- Renault Megane

Kriterij	Jedinica/Skala
Cijena	Tisuće eura
Snaga	kW
Prosječna potrošnja	L/100km
Udobnost i prostranost	Opisna skala(od vrlo loša do vrlo dobra)
EuroNCAP	Opisna skala(1 do 5 zvjezdica)

Tablica 3.3: Kriteriji za usporedbu automobila

Nakon dobivenih svih podataka od strane ovlaštenih prodavača automobila marki koje će biti uspoređivane, određeni su kriteriji za uspoređivanje automobila u tablici 3.3 i težina svakoga kriterija u tablici 3.4.

## 3.2. Odabir automobila

MARKA	I	II	III	IV	V	VI	VII	VIII	IX	X	X 2010 %	UKUPNO		2009			
												2010 Kom.	2010 %	X		I-X	
														Kom.	%	Kom.	%
1 Opel	320	381	514	415	405	356	654	380	349	273	9,29%	4025	12,59%	281	8,47%	4277	11,11%
2 Volkswagen	359	340	371	369	403	512	467	196	285	251	8,60%	3553	11,11%	349	10,52%	3680	9,56%
3 Renault	206	271	277	272	240	269	300	222	274	303	10,39%	2694	8,42%	313	9,43%	3474	9,02%
4 Chevrolet	201	305	292	251	300	264	281	215	349	211	7,23%	2669	8,41%	117	3,53%	1690	4,39%
5 Peugeot	209	241	215	205	298	310	217	214	163	223	7,64%	2295	7,18%	187	5,63%	3011	7,82%
6 Hyundai	187	165	185	176	212	219	254	150	141	177	6,07%	1866	5,83%	189	5,69%	1605	4,17%
7 Škoda	168	179	184	177	243	278	182	116	147	133	4,49%	1805	5,64%	204	7,95%	2155	5,60%
8 Ford	78	120	149	194	281	197	175	254	125	146	5,01%	1719	5,37%	160	4,82%	2258	5,86%
9 Citroen	138	138	188	155	151	207	207	111	121	173	6,00%	1591	4,97%	312	9,40%	2349	6,10%
10 Kia	52	52	76	80	122	110	108	98	127	141	4,83%	966	3,02%	100	3,01%	1277	3,32%
11 Mazda	96	102	102	111	96	85	109	81	101	80	2,74%	963	3,01%	133	4,01%	1275	3,31%
12 Toyota	93	85	77	88	98	94	123	73	106	114	3,91%	951	2,97%	114	3,43%	1569	4,07%
13 Suzuki	87	104	112	86	97	84	114	69	93	86	2,95%	932	2,91%	107	3,22%	1515	3,93%
14 Dacia	51	89	80	87	88	98	102	95	100	83	3,02%	878	2,75%	38	1,14%	748	1,94%
15 Nissan	37	40	63	72	99	103	78	60	79	67	2,30%	698	2,18%	75	2,29%	1021	2,65%
16 Seat	41	56	77	76	84	96	59	52	65	70	2,40%	676	2,11%	54	1,63%	807	2,10%
17 BMW	66	47	78	69	62	60	87	47	70	70	2,40%	656	2,05%	58	1,75%	596	1,55%
18 Audi	56	50	59	55	60	86	83	33	70	63	2,16%	615	1,92%	67	2,02%	772	2,01%
19 Fiat	36	77	149	30	73	38	42	53	51	46	1,58%	595	1,86%	76	2,29%	1239	3,22%
20 Mercedes	16	16	44	34	94	77	130	55	55	73	2,50%	594	1,86%	112	3,37%	808	2,10%
21 Honda	50	42	47	56	62	35	54	38	67	42	1,44%	473	1,48%	103	3,10%	970	2,53%
22 Volvo	12	11	19	9	15	10	18	12	12	19	0,65%	137	0,43%	22	0,69%	238	0,62%
23 Smart	8	7	11	14	20	10	12	1	13	17	0,58%	113	0,35%	24	0,72%	176	0,46%
24 Lada	10	6	8	9	10	7	14	7	5	7	0,24%	83	0,26%	12	0,36%	155	0,40%
25 Mitsubishi	1	2	3	3	6	23	8	4	2	4	0,14%	66	0,21%	3	0,09%	165	0,43%
26 Alfa Romeo	4	7	8	2	2	4	5	1	5	17	0,58%	55	0,17%	5	0,15%	147	0,38%
27 Lancia	6	7	6	5	9	3	5	5	1	4	0,14%	51	0,16%	7	0,21%	96	0,25%
28 Mini	3	2	3	6	3	4	4	2	8	5	0,17%	40	0,13%	6	0,18%	51	0,13%
29 Saab	10	3	7	1	3	5	5	1	1	1	0,03%	37	0,12%	8	0,24%	25	0,06%
30 Subaru	3	2	9	5	3	2	3	3	2	4	0,14%	34	0,11%	3	0,09%	66	0,17%
31 Land Rover	5	0	5	1	3	4	1	4	4	2	0,07%	29	0,09%	2	0,06%	38	0,10%
32 Porsche	2	2	2	3	0	1	5	4	3	5	0,17%	27	0,08%	3	0,09%	41	0,11%
33 Jeep	6	2	5	2	0	2	1	1	1	0	0,00%	20	0,06%	7	0,21%	82	0,21%
34 Lexus	3	2	2	0	1	3	2	0	3	0	0,00%	16	0,05%	2	0,06%	51	0,13%
35 Infiniti	0	0	0	0	0	1	0	5	2	4	0,14%	12	0,04%	0	0,00%	4	0,01%
36 Jaguar	1	1	1	1	3	1	3	1	0	0	0,00%	12	0,04%	1	0,03%	13	0,03%
37 Tata	0	0	1	1	2	1	0	0	0	0	0,00%	5	0,02%	1	0,03%	3	0,01%
38 Aston Martin	0	0	0	2	2	0	0	0	0	0	0,00%	4	0,01%	0	0,00%	3	0,01%
39 Maserati	0	0	0	0	0	0	1	0	1	0	0,00%	2	0,01%	0	0,00%	0	0,00%
40 Acura	0	0	0	0	0	1	0	0	0	0	0,00%	1	0,00%	0	0,00%	0	0,00%
41 Chrysler	0	0	0	0	1	0	0	0	0	0	0,00%	1	0,00%	3	0,09%	11	0,03%
42 Dodge	0	0	0	0	0	1	0	0	0	0	0,00%	1	0,00%	0	0,00%	12	0,03%
43 Opel	0	0	0	0	0	0	0	0	0	0	0,00%	0	0,00%	1	0,03%	24	0,06%
UKUPNO	2601	2954	3429	3122	3661	3691	3953	2663	3001	2917	100%	31982	100%	3319	100%	38506	100%

Slika 3.9: Najprodavanije marke automobila 2010. godine u Hrvatskoj

Kriterij	Težina kriterija
Cijena	30
Snaga	15
Prosječna potrošnja	30
Udobnost i prostranost	15
EuroNCAP	10

Tablica 3.4: Težina kriterija

Sljedeći korak u provedbi PROMETHEE metode je maksimiziranje pojedinih kriterija (snaga, udobnost i prostranost, euroNCAP), te minimiziranje preostalih (cijena i prosječna potrošnja). Posljednji korak prije unosa podataka u Decision Lab proračunsku tablicu potrebno je odrediti tip općeg kriterija po kojemu ćemo uspoređivati alternative. Za cijenu i prosječnu potrošnju koristiti će se kriterij s linearnom preferencijom,

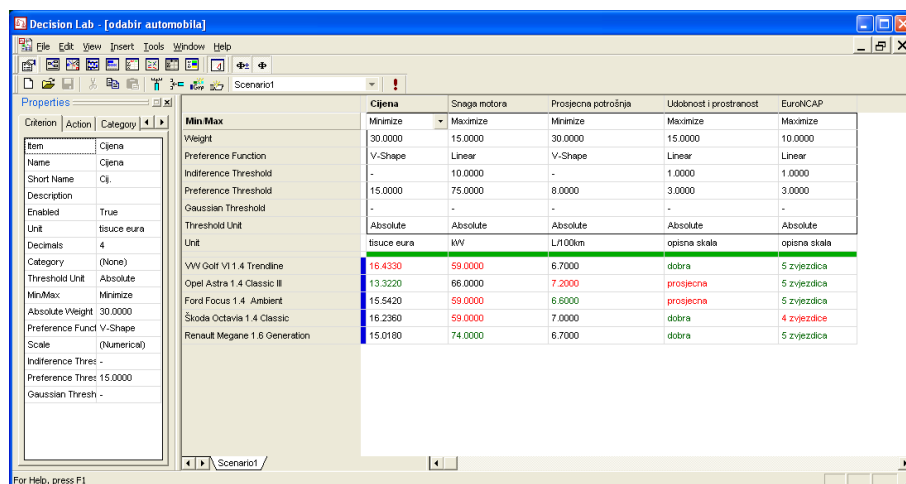


## 3.2. Odabir automobila

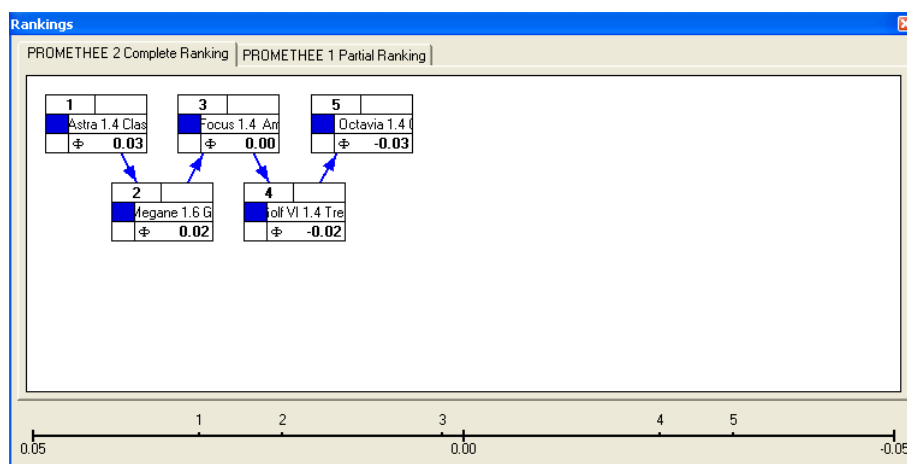
	MODEL	I	II	III	IV	V	VI	VII	VIII	IX	X	X 2010 %	UKUPNO 2010 Kom.	UKUPNO 2010 %	2009			
															X		I-X	
															Kom.	%	Kom.	%
1	Opel Astra	182	203	228	164	198	139	326	191	158	137	5,31%	1944	6,08%	176	5,50%	2667	6,95%
2	Volkswagen Polo	168	159	155	183	126	245	198	80	117	98	3,36%	1529	4,78%	166	5,00%	850	2,21%
3	Opel Corsa	80	100	160	148	118	116	219	128	116	62	2,13%	1247	3,90%	59	1,78%	178	0,02%
4	Volkswagen Golf	102	87	128	95	130	130	142	40	73	98	3,39%	1026	3,21%	91	2,74%	1485	3,88%
5	Renault Megane	76	87	95	116	89	97	154	86	121	107	3,53%	1024	3,20%	107	3,22%	1176	3,05%
6	Škoda Octavia	65	80	82	94	104	121	82	38	68	65	2,06%	812	2,54%	84	2,53%	1034	2,69%
7	Renault Clio	82	121	91	63	69	71	99	30	52	84	3,22%	792	2,48%	134	4,04%	1375	3,57%
8	Peugeot 308	68	60	65	58	69	131	73	99	81	82	2,81%	766	2,40%	59	1,78%	960	2,34%
9	Chevrolet Cruze	72	85	68	69	82	66	73	73	83	57	1,95%	728	2,28%	17	0,51%	125	0,32%
10	Hyundai i30	84	95	117	57	62	54	100	32	45	60	2,06%	706	2,21%	88	2,65%	523	1,36%
11	Ford Focus	51	49	75	83	146	67	57	101	31	37	1,20%	693	2,17%	70	2,11%	1121	2,91%
12	Škoda Fabia	74	72	65	53	104	119	60	38	57	44	1,51%	686	2,14%	118	3,56%	827	2,15%
13	Kia Ceed	35	36	49	56	93	91	96	76	79	71	2,43%	682	2,13%	82	2,47%	915	2,38%
14	Chevrolet Lacetti	19	82	37	24	77	93	86	77	107	73	2,43%	673	2,10%	2	0,06%	93	0,24%
15	Dacia Sandero	40	73	62	76	73	81	73	55	62	56	1,92%	651	2,04%	27	0,81%	488	1,27%
16	Chevrolet Aveo	45	51	82	88	79	77	89	27	72	33	1,06%	641	2,00%	38	1,14%	789	2,05%
17	Ford Fiesta	27	48	43	42	90	105	71	92	48	70	2,40%	636	1,99%	44	1,33%	588	1,53%
18	Hyundai i20	60	40	27	46	75	66	77	85	40	43	1,47%	559	1,75%	60	1,81%	348	0,90%
19	Peugeot 207	68	60	44	38	69	67	20	37	36	61	2,09%	520	1,66%	42	1,27%	881	2,29%
20	Škoda SX4	58	63	72	56	53	41	70	33	37	32	1,10%	515	1,61%	80	2,41%	979	2,54%
21	Ortak	1167	1303	1484	1513	1745	1714	1758	1255	1518	1533	52,55%	15140	47,34%	1755	53,68%	20554	53,38%
	UKUPNO	2601	2954	3429	3122	3651	3691	3953	2663	3001	2917	100%	31982	100%	3319	100%	38506	100%

Slika 3.10: Najprodavaniji modeli automobila 2010. godine u Hrvatskoj

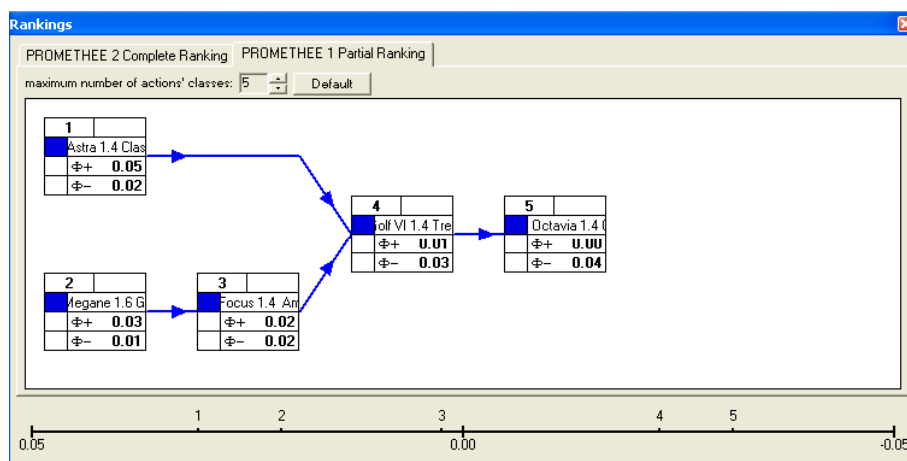
a za preostale će se koristiti kriterij s linearnom preferencijom i područjem indiferencije.



Slika 3.11: Unos podataka



Slika 3.12: PROMETHEE II potpuno rangiranje




Slika 3.13: PROMETHEE I parcijalno rangiranje

Stability Intervals


Stability Level: 2 | first actions | ☐ AutoLevel

	Weight	Interval		% Weight	% Interval	
		Min	Max		Min	Max
Cijena	30.0000	22.7061	Infinity	30.00%	24.49%	100.00%
Snaga motora	15.0000	0.0000	32.8683	15.00%	0.00%	27.89%
Prosječna potrošnja	30.0000	0.0000	43.1951	30.00%	0.00%	38.16%
Udobnost i prostora	15.0000	0.0000	Infinity	15.00%	0.00%	100.00%
EuroNCAP	10.0000	0.0000	Infinity	10.00%	0.00%	100.00%

Slika 3.14: Intervali stabilnosti



Slika 3.15: GAIA ravnina



Slika 3.16: Težina kriterija

**Preference Flows**

	$\Phi+$	$\Phi-$	$\Phi$
<b>VW Golf VI 1.4 Trendline</b>	0.0075	0.0319	-0.0244
Opel Astra 1.4 Classic III	0.0497	0.0169	0.0328
Ford Focus 1.4 Ambient	0.0192	0.0166	0.0026
Škoda Octavia 1.4 Classic	0.0029	0.0364	-0.0335
Renault Megane 1.6 Generatio	0.0319	0.0094	0.0225

Slika 3.17: Izlazni, ulazni i čisti tok

## Zaključak

Cilj završnog rada bio je opisati problematiku višekriterijalnog odlučivanja i "PROMETHEE" metodu rješavanja višekriterijalnih problema, te primjeniti "PROMETHEE" metodu na dva praktična problema višekriterijalnog odlučivanja uz pomoć aplikacije "Decision Lab". Metoda "PROMETHEE" primjenjuje se zato jer dozvoljava donositelju odluke izravno korištenje podacima za postavljeni problem u jednostavnoj višekriterijskoj tablici; donositelj odluke sam definira mjernu skalu, te označava svoje prioritete i preferencije za svaki kriterij; omogućava analitičko i grafičko rješavanje problema (Decision Lab), te je bogata podacima i informacijama potrebnim za donošenje optimalnog rješenja. Analizom primjera pokazano je da je "PROMETHEE" metoda korisna u praktičnoj primjeni i da su dobiveni rezultati iskoristivi prilikom donošenja bilo odluke o izboru lokacije novog postrojenja ili odabiru (kupnji) novog automobila. Rezultati variraju ovisno o zadanim težinama kriterija, preferencijama i preferencijskim funkcijama kao što je pretpostavljeno prilikom opisa same "PROMETHEE" metode i njezine praktične primjene. Prilikom izrade rada u prvi plan je stavljen opis same metode kao i primjena na dva praktična primjera, a kao daljne područje proučavanja ove metode pojavljuje se mogućnost istraživanja preferencijskih funkcija, njihovih svojstava i karakteristika, kao i način njihova poboljšavanja kako bi se u dogledno vrijeme te "modificirane" preferencijske funkcije mogle primjeniti na specifične probleme koji se pojavljuju unutar različitih područja industrije i gospodarstva.

---

## Bibliografija

- [1] RADOJIČIĆ M. i ŽIŽOVIĆ M., Primjena Metoda Višekriterijumske Analize u Poslovnom Odlučivanju, Tehnički Fakultet u Čačku, (1998.)
- [2] BRANS J.P., Centrum voor Statistiek en Operationeel Onderzoek Vrije Universiteit Brussel Pleinlaan 2, B-1050 Brussels, Belgium., PROMETHEE METHODS
- [3] HATAMURA Y., Decision-Making in Engineering Design, Springer, (2006.)
- [4] BRANS J.P i MARESCAL B., How to Decide with PROMETHEE, ULB and VUB Brussels Free Universities
- [5] KAHRAMAN C., Fuzzy Multi-Criteria Decision Making, Springer, (2008.)
- [6] SCHALLER A., Izbor mjesta odlagališta nisko i srednje radioaktivnog otpada u Republici Hrvatskoj, MI-PRINT, Zagreb (1997.)
- [7] MLADINEO N., Podrška izvođenju i odlučivanju u graditeljstvu, Građevinsko-arhitektonski fakultet Sveučilišta u Split
- [8] [www.autozubak.hr](http://www.autozubak.hr)
- [9] [www.opel.hr](http://www.opel.hr)
- [10] [www.renault.hr](http://www.renault.hr)
- [11] [www.ford.hr](http://www.ford.hr)
- [12] [www.euroncap.com](http://www.euroncap.com)
- [13] [www.4kotaca.net](http://www.4kotaca.net)

[14] [www.promocija-plus.com](http://www.promocija-plus.com)

[15] [www.visualdecision.com](http://www.visualdecision.com)